

**SVEUČILIŠTE U ZAGREBU  
AGRONOMSKI FAKULTET**

**PROCJENA GENETSKIH PARAMETARA ZA SVOJSTVA  
OBLIKA VIMENA ISTARSKE OVCE**

**DIPLOMSKI RAD**

**Petra Furdić**

**Zagreb, rujan, 2017.**

**SVEUČILIŠTE U ZAGREBU  
AGRONOMSKI FAKULTET**

Diplomski studij:  
Genetika i oplemenjivanje životinja

**PROCJENA GENETSKIH PARAMETARA ZA SVOJSTVA  
OBLIKA VIMENA ISTARSKE OVCE**  
DIPLOMSKI RAD

Petra Furdić

Mentor: prof. dr. sc. Alen Džidić  
Neposredni voditelj: doc. dr. sc. Dragica Šalamon

Zagreb, rujan, 2017.

**SVEUČILIŠTE U ZAGREBU  
AGRONOMSKI FAKULTET**

**IZJAVA STUDENTA  
O AKADEMSKOJ ČESTITOSTI**

Ja, **Petra Furdić**, JMBAG 0178090912, rođena dana 23.02.1993. u Zagrebu, izjavljujem  
da sam samostalno izradila diplomski rad pod naslovom:

**PROCJENA GENETSKIH PARAMETARA ZA SVOJSTVA OBLIKA VIMENA ISTARSKE OVCE**

Svojim potpisom jamčim:

- da sam jedina autorica ovoga diplomskog rada;
- da su svi korišteni izvori literature, kako objavljeni tako i neobjavljeni, adekvatno citirani ili parafrazirani, te popisani u literaturi na kraju rada;
- da ovaj diplomski rad ne sadrži dijelove radova predanih na Agronomskom fakultetu ili drugim ustanovama visokog obrazovanja radi završetka sveučilišnog ili stručnog studija;
- da je elektronička verzija ovoga diplomskog rada identična tiskanoj koju je odobrio mentor;
- da sam upoznata s odredbama Etičkog kodeksa Sveučilišta u Zagrebu (Čl. 19).

U Zagrebu, dana 11. rujna 2017.

---

*Potpis studentice*

**SVEUČILIŠTE U ZAGREBU  
AGRONOMSKI FAKULTET**

**IZVJEŠĆE**

**O OCJENI I OBRANI DIPLOMSKOG RADA**

Diplomski rad studentice **Petre Furdić**, JMBAG 0178090912, naslova

**PROCJENA GENETSKIH PARAMETARA ZA SVOJSTVA OBLIKA VIMENA  
ISTARSKE OVCE**

obranjen je i ocijenjen ocjenom \_\_\_\_\_, dana \_\_\_\_\_.

Povjerenstvo:

potpisi:

- |    |                              |                     |       |
|----|------------------------------|---------------------|-------|
| 1. | prof. dr. sc. Alen Džidić    | mentor              | _____ |
|    | doc. dr. sc. Dragica Šalamon | neposredni voditelj | _____ |
| 2. | prof. dr. sc. Miroslav Kapš  | član                | _____ |
| 3. | prof. dr. sc. Ino Čurik      | član                | _____ |

## **Zahvala**

Ovime zahvaljujem svima koji su mi pomogli pri izradi ovog diplomskog rada svojim djelima, savjetima, preporukama i ostalim ne tako beznačajnim stanicama.

Hvala mom mentoru prof. dr. sc. A. Džidiću na ustupljenoj temi rada. Hvala prof. dr. sc. M. Kapšu na velikoj pomoći i znanju. Posebno hvala mojoj neposrednoj, ali velikoj voditeljici doc. dr. sc. Dragici Šalamon, bez koje ovo ništa ne bi imalo smisla. Hvala joj na svom ustupljenom vremenu, volji, trudu i velikom znanju i energiji koje je prenjela.

Hvala mojim dvjema obiteljima na svim ručkovima i podršci. Hvala mom Igoru na ljubavi, podršci i snazi koja je bila tako potreba.

Na kraju posebno hvala mom najboljem prijatelju Toniju Tešiji bez kojeg ovo ništa ne bi bilo toliko zabavno. Za ovo uspješno i zanimljivo zajedničko studiranje.

## Sadržaj

1.	Uvod .....	1
1.1.	Cilj rada .....	2
2.	Istarska ovca .....	3
2.1.	Morfologija vimena .....	4
2.2.	Odnos morfologije vimena i strojne mužnje ovaca .....	5
3.	Uzgojna vrijednost .....	7
4.	Animal model.....	8
5.	Materijali i metode .....	11
5.1.	Opis i čišćenje pedigrea .....	11
5.2.	Opis i čišćenje podataka .....	12
5.3.	Opis i raspodjela mjerenja pune visine vimena (Fh) .....	24
5.4.	Opis i raspodjela mjerenja maksimalne širine vimena (Mw) .....	27
5.5.	Opis i raspodjela mjerenja visine cisterne koja se nalazi ispod otvora sisnog kanalića (Cis).....	29
5.6.	Opis i raspodjela mjerenja kuta sise (Alfa) .....	32
6.	Modeli za procjenu genetskih parametara.....	35
7.	Rezultati.....	37
7.1.	Genetske analize svojstva oblika vimena istarske ovce .....	37
8.	Rasprava .....	38
9.	Zaključak .....	39
10.	Literatura .....	40

## **Sažetak**

Diplomskog rada studentice **Petre Furdić**, naslova

### **PROCJENA GENETSKIH PARAMETARA ZA SVOJSTVA OBLIKA VIMENA ISTARSKE OVCE**

Istarska ovca je lokalna mliječna pasmina s morfologijom vimena pogodnom za strojnu mužnju, koju je potrebno očuvati u budućim selekcijama. U ovom radu prikazana je analiza kvalitete podataka opisnim statističko-numeričkim i grafičkim metodama, te je izvršena procjena genetskih parametara za svojstva oblika vimena. Vanjski oblik vimena istarske ovce mjereno je na 11 komercijalnih farmi tri puta tijekom laktacije i uključuje: punu visinu vimena (Fh), maksimalnu širinu vimena (Mw), kut koji sisa zatvara s vertikalnom osi vimena (Alfa) i visinu cisternalnog dijela vimena koji se nalazi ispod otvora sisinog kanalića (Cis). Uzgojne vrijednosti procjenjivane su pomoću animal modela korištenjem procedure MIXED u računalnom programu SAS. Procijenjeni heritabiliteti za oblik vimena iznosili su 0.71 za Cis i 0.05 za Alfa. Dobiveni rezultati pokazuju da bi visina cisterne ispod sisnog kanalića bila pogodna za selekciju zbog visokog heritabiliteta.

**Ključne riječi:** animal model, genetski parametri, morfologija vimena

## **Summary**

Of the master's thesis – student **Petra Furdić**, entitled

### **EVALUATION OF GENETIC PARAMETERS FOR THE UDDER MORPHOLOGY OF ISTRIAN SHEEP**

Istrian sheep is a local dairy breed with a good udder morphology, which needs to be preserved in future selections. This paper presents the analysis of data quality by descriptive statistical-numerical and graphical methods, and the evaluation of genetic parameters for the udder morphology. Udder morphology of the Istrian sheep was measured on 11 commercial farms three times during lactation and includes: full height (Fh), maximum width (Mw), the teat angle (Alfa ) and the height of the cisternal part below the teat orifice (Cis). Heritabilities were estimated using an animal model using the MIXED procedure in the SAS program. The udder shape heritabilities were 0.71 for and 0.05 for Alpha. Obtained results show that Cis trait could be suitable for selection due to high heretability.

**Keywords:** animal model, genetic parametars, udder morphology



## 1. Uvod

Istarska ovca jedna je od devet hrvatskih izvornih pasmina ovaca koja je nastala i uzgaja se gotovo isključivo na području istarskog poluotoka. Mlijeko ove ovce se većinom prerađuje u polutvrđi istarski sir.

Vime ili mliječna žlijezda jedinstvena je žlijezda u organizmu životinje jer ima važnu funkciju u razvoju i životu sisavaca. Anatomska građa, razvijenost i zdravlje vimena od presudne su važnosti za količinu i sastav proizvedenog mlijeka. Veličina, oblik i izgled vimena u velikoj su mjeri genetski određeni (Fernandez i sur., 1997) i imaju važnu ulogu u strojnoj mužnji, odnosno učinkovitost strojne mužnje ovisi o morfologiji vimena.

Selekcija mliječnih ovaca je sve donedavno, gotovo isključivo, bila usmjerena na povećanje mliječnosti, odnosno izlučivanje grla s malom količinom proizvedenoga mlijeka, kao i onih s velikim brojem somatskih stanica u mlijeku. Međutim, posljednjih dvadesetak godina povećan je interes za istraživanjem morfologije vimena u mliječnim pasmina ovaca. Utvrdili su se različiti čimbenici njezine varijabilnosti, ne samo glede prikladnosti vimena strojnoj mužnji, već i s motrišta količine i kvalitete proizvedenoga mlijeka te zdravlja vimena, kao i proizvodne dugovječnosti ovaca. Cilj je bio identificirati one odlike vimena i sisa pogodnih za uvrštavanje u selekcijske programe (Barillet, 2007).

Učinkovitost strojne mužnje ovisi o morfologiji vimena. Prvotni selekcijski planovi za mliječne ovce bili su usmjereni prvenstveno na prinos i sastav mlijeka, što negativno utječe na morfologiju vimena jer se povećava cisternalni dio vimena ispod sisnog otvora i povećava kut koji sisa zatvara s vertikalnom osi vimena. Najvažnije morfološke odlike koje određuju prikladnost vimena strojnoj mužnji su visina mliječne cisterne te kut i položaj sisa. Što je vertikalniji položaj, odnosno što je manji kut sisa, to je lakše i brže izmuzivanje mlijeka. (Labussière, 1988).

Za razliku od pasmina ovaca selektiranih na visoku mliječnost, u neselektiranih lokalnih mliječnih pasmina, kao što je istarska ovca, postoji morfologija vimena pogodna za strojnu mužnju koju je potrebno očuvati u budućoj selekciji. Zato je potrebno procijeniti genetske parametre svojstava oblika vimena, jer to omogućuje korektnu procjenu uzgojnih vrijednosti i posljedično izbor rasplodnih životinja s povoljnim oblikom vimena (Šalamon, 2013).

## **1.1. Cilj rada**


Cilj ovog rada je analizirati kvalitetu podataka opisnim statističko-numeričkim i grafičkim metodama, uključujući i empirijsku raspodjelu podataka, te procijeniti genetske parametre svojstva oblika vimena istarske ovce koji uključuju: punu visinu vimena ( $F_h$ ), maksimalnu širinu vimena ( $M_w$ ), kut koji sisa zatvara s vertikalnom osi vimena ( $\alpha$ ) i visinu cisternalnog dijela vimena koji se nalazi ispod otvora sisinog kanalića ( $C_{is}$ ).

## 2. Istarska ovca

Istarska ovca jedna je od devet hrvatskih izvornih pasmina ovaca koja je nastala i uzgaja se gotovo isključivo na području istarskog poluotoka. Jedinstvene je vanjštine sa konveksnom nosnom kosti, dugim nogama, razvijenim rogovima. Temeljna boja runa je bijela sa crnim, smeđim ili crno-smeđim pjegama. Pripada skupini kombiniranih pasmina (mlijeko-meso-vuna), ali po proizvodnim odlikama više se može svrstati u mliječne pasmine (Mioč i sur., 2012).

Mlijeko ove ovce se većinom prerađuje u polutvrđi istarski sir. Mliječnost je dobra i tako za 178 do 193 dana laktacije proizvede 168 do 214 litara mlijeka. Najvažniji proizvodi istarske ovce su mlijeko, istarski sir, janjetina i skuta (<https://www.agroklub.com/baza-stocarstva/ovcarstvo/istarska-ovca-40/>, 21.3.2017).

Danas se važnost istarske ovce očituje ne samo kroz njezinu komercijalnu ulogu, već i kroz vrijednost i jedinstvenost genoma, odnosno kao potencijalni izvor interesantnih gena za poboljšanje i održavanje poželjne otpornosti na različite bolesti i uvjete okoliša. Naime, upravo adaptabilnost istarske ovce u području u kojem je nastala te u kojemu ju se i trenutačno primarno uzgaja, a razmjerno uloženom i relativno zadovoljavajuća proizvodnost, osobito mliječnost, potvrđuje njenu istinsku proizvodnu učinkovitost i gospodarsku vrijednost (Mioč i sur., 2012).



Slika 2.1. Istarska ovca

## 2.1. Morfologija vimena

Vime je složena mjehurastocjevasta egzokrina kožna žlijezda, koja uključuje mliječnu žlijezdu, cisternu, sise, te suspenzorni sustav. Građena je iz žljezdanog parenhima i vezivnog tkiva. Svaka žlijezda posjeduje vlastiti dobro razvijeni i razgranati kanalni sustav, koji je u svojim perifernim dijelovima podijeljen u režnjeve i režnjiće vezivnotkivnim pregradama, koje su dijelovi suspenzornog sustava i predstavljaju stromu vimena. Režnjići su izgrađeni od alveola koje su mikroskopske građe i koje su osnovne funkcionalne sekrecijske jedinice. Šupljina alveole nastavlja se u odvodni kanalić koji predstavlja početak kanalnog sustava. Intralobularni ili kanali unutar režnjića sjednjuju se u interlobularne kanale iliti kanale iz režnjeva, a oni se postupno proširuju i odlaze u mliječnu cisternu (*lat. sinus lactifera*), smještenu u najdonjem dijelu četvrti (Džidić, 2013). Iz mliječnih cisterni mlijeko teče papilarnim kanalićima kroz sisne otvore. Svaka sisa ima po jednu cisternu i jedan sisni kanal izvana zatvoren kružnim mišićem (sfinkterom). Sisni kanal je jedina spona između mliječne žlijezde i vanjske okoline. On služi kao glavna barijera protiv raznih infekcija (Hogan i sur., 1987). Marnet i McKusick (2001) su u mliječnim ovaca utvrdili da je od ukupne količine pomuzenog mlijeka oko 75 % iz cisterne, a preostalih 25 % je iz alveola. Mlijeko se stvara za vrijeme gravidnosti i u ranoj laktaciji pod utjecajem neuro-endokrinog i autokrinog sustava (Caja i sur., 2000).

Kroz godine se javio sve veći interes i potreba uzgajivča za strojnom mužnjom, a samim time je u selekciji muznih ovaca bilo neophodno voditi računa o razvijenosti i tipu vimena te položaju sisa i, općenito, o morfologiji vimena. Sve je to učinjeno s ciljem genetskog poboljšanja prikladnosti vimena strojnoj mužnji. Poželjan i pravilan izgleda vimena nije jasno određen i ovisi o pasmini i namjeni grla. Vime mesnih i mliječnih pasmina se razlikuju. Visokomliječne pasmine ovaca, osobito one koje se muze strojno, trebale bi imati okruglo vime, velikog obujma (volumena), koje je dobro pričvršćeno za trbuh. Trebalo bi biti osrednje dubine, ne prelazeći visinu skočnog zgloba. Trebalo bi imati srednje velike sise (duljina i širina), postavljene vertikalno, imati meko i elastično tkivo, s dobro opipljivim žljezdanim cisternama, te imati dobro izražen intermamarni žlijeb (Caja i sur., 2000).

Vime istarske ovce je poprilično dobro razvijeno i relativno veliko, s mekim i elastičnim žljezdanim tkivom te na dodir dobro opipljivim mliječnim cisternama. U većine istarskih ovaca vime je pigmentirano (svijetlosmeđe ili tamnosmeđe, smeđe-bijelo, crno-bijelo, dominantno crno i sl.), te slabo do umjereno prekriveno dlačicama. (Prpić i sur., 2008).



Slika 1.2. Pravilno razvijeno vime istarske ovce



Slika 2.3. Nepravilno razvijeno vime istarske ovce

## 2.2. Odnos morfologije vimena i strojne mužnje ovaca

U Hrvatskoj je primijećen sve veći interes za strojnu mužnju ovaca. Možemo reći da je strojna mužnja istarske ovce prisutna u određenoj mjeri za razliku od drugih autotoničkih pasmina ovaca Hrvatske koje se najčešće muzu ručno (Džidić, 2013). Morfologija mliječne žlijezde je važan faktor u određivanju sposobnosti ovaca za strojnu mužnju (Šalamon, 2013).

Prednosti strojne mužnje su maksimalna količina higijenski ispravnog mlijeka, a njome je ujedno olakšana i zadnja faza mužnje, to jest izmuzivanje (Džidić, 2013). Istraživanja su pokazala da strojna mužnja, kada se primijenjuje na vime dobre morfologije ima pozitivni učinak na zdravlje vimena, kvalitetu mlijeka, smanjenje subkliničkog i kliničkog mastitisa (Bergonier i sur. 2003; Fernandez i sur., 1997; Legerra i Ugarte, 2000; Marie-Etancelin i sur.,

2001). U svojem je istraživanju Labussiere (1988) govorio o morfologiji kao selekcijskom kriteriju za svojstvo mlječnosti ovaca. Govorio je o potrebi za okomito postavljenim sisama u najnižem dijelu cisterne. Ubrzo nakon povećan je interes za vime mliječnih ovaca, a razlog tomu bilo je „vrećasto vime“ (eng. „*baggy udder*“), pronađeno u ovaca selektiranih na visoku mlječnost. Kod tih ovaca, cisternalni dio vimena ispod sisnog otvora je bio veći pa je samim time bio povećan i kut između sise i vertikalne osi vimena (De La Fuente, 1996; Fernandez i sur., 1997; Marie-Etancelin i sur., 2005).

Mužnja takvog „vrećastog vimena“ nije pogodna, jer dio cisternalnog mlijeka zaostaje ispod sisnog otvora, osim ako se ne primjeni ručnu manipulaciju vimena tijekom skidanja (Bruckmaier i sur., 1997; Bruckmaier i Blum, 1998). Uz to, vodoravno postavljene sise ne mogu držati težinu muzne jedinice i one zbog tog padaju. Ta vrsta dodatne manipulacije tijekom mužnje produljuje ukupno vrijeme mužnje stada. To također može dovesti do neadekvatno pomuzenog vimena što nije dobro za zdravlje samog vimena i može se odraziti na ukupan dnevni prinos cijelog stada (Gelasakis i sur., 2012).

### **3. Uzgojna vrijednost**

Dobru morfologiju vimena istarske ovce potrebno je očuvati u budućim selekcijama i zato je potrebno procijeniti genetske parametre svojstava oblika vimena, jer to omogućuje korektnu procjenu uzgojnih vrijednosti i posljedično izbor rasplodnih životinja s povoljnim oblikom vimena.

Uzgojna vrijednost (UV) ili drugim riječima aditivna genetska vrijednost predstavlja prosječni aditivni utjecaj gena koje životinja dobije od oba roditelja. Kako je aditivni dio genotipa funkcija gena dobivenih od roditelja, to je najčešće dio genotipa na koji se može vršiti selekcija. Što točnija procjena uzgojne vrijednosti je vrlo važna, jer genetsko poboljšanje kroz selekciju zavisi o točnoj identifikaciji jedinki sa najvećom uzgojnom vrijednosti. Točnost procjene ovisi o količini informacija, veličini i točnosti procjena genetskih parametara. UV se najjednostavnije može procijeniti unutar neke populacije ili grupe koje žive u gotovo jednakim uvjetima. U istraživanjima gdje se procjenjuje UV životinja, cilj je smanjiti utjecaje okoliša. To se provodi kako bi se dobivene razlike u vrijednostima mogle tumačiti kao posljedica različitih aditivnih vrijednosti. Odnosno, nastoji se dokazati da je neka životinja bolja zbog njene aditivne vrijednosti. U procjenama UV se uz smanjenje utjecaja okoliša nastoji dobiti što veći broj mjerenja na što većem broj životinja koje žive u što sličnijim uvjetima kako bi se povećala točnost procjene (Mrode, 2005). Potrebno je izgraditi adekvatan model za procjenu uzgojnih vrijednosti koji će koristiti i informacije o proizvodnji, pedigreu, rođacima i okolini.

## 4. Animal model

Animal model je oblik mješovitog modela koji procjenjuje uzgojne vrijednosti jedinki. To je mješoviti model u kojem je slučajni utjecaj sama životinja, odnosno njena aditivna genetska vrijednost, a istovremeno koristi pedigree u definiranju genetske veze među životinjama. Taj model, dakle, koristi sve raspoložive izvore informacija: mjerenja, porijeklo, procjenu parametara i razlike u okolišnim uvjetima. Iz navedenog je vidljivo da su u izračune uzgojne vrijednosti uvršteni i sistematski i slučajni utjecaji kako bi se dobila najtočnija procjena uzgojne vrijednosti (Wilson i sur. 2010).

Razne studije koriste taj oblik mješovitog modela poznatog kao animal model kako bi rastavili fenotipsku varijancu na različite genetske i okolišne čimbenike i kako bi procijenili ključne parametre za uzgoj kao što su heritabilitet i svojstva genetske korelacije. Ovaj pristup kao i svi drugi u kvantitativnoj genetici traže znanje povezanosti jedinki u populaciji (obiteljske veze). Za jedno svojstvo možemo procijeniti fenotipsku varijancu ( $V_p$ ) koja je rezultat razlike između jedinki. Genetske razlike između jedinki sastavljene su od aditivne varijance ( $V_a$ ), varijance dominacije ( $V_d$ ) i interakcije ili epistaze ( $V_i$ ).  $V_d$  i  $V_i$  je teško procijeniti u neeksperimentalnim uvjetima. U jednostavnim slučajevima, za procjenu se uključuje statističko razlaganje fenotipske varijance na dva dijela:  $V_p = V_a + V_r$  gdje je  $V_r$  ostatak.  $V_r$  se obično tumači kao posljedica utjecaja okoliša. Heritabilitet u užem smislu ( $h^2$ ) je zbog toga definiran kao proporcija fenotipske i aditivne varijance i opisuje stupanj nasljednosti nekog svojstva (Wilson i sur., 2009). Komponente varijance slučajnih utjecaja, kao što je aditivna genetska i varijanca stalnog i promijenjivog okoliša lako je razdijeliti u velikim populacijama (Fischer i sur., 2004); no u relativno malim populacijama, zbog relativno male količine informacija, dolazi do problema u modeliranju i razdijeljivanju komponenti varijance sa poželjnom točnošću (Kapš i sur., 2010).

Animal model uzima u obzir svu poznatu srodnost između životinja i na taj način je moguće predvidjeti uzgojnu vrijednost za svaku životinju, bez obzira ima li ona vlastito mjerenje i samim time povećava se točnost procjene. Točnost procjene (*eng. accuracy*) definira se kao korelacija između pravih i procijenjenih uzgojnih vrijednosti, odnosno to nam je mjera pouzdanosti procjene uzgojnih vrijednosti. Animal modelom smanjuje se pristranost zbog neslučajnog parenja i zbog genetskog trenda (Mrode, 2005.) U mješovite modele prema definiranom slučajnom utjecaju, u koje spada i animal model, spadaju još i model očeva (*eng. sire model*), model s ponavljajućim mjerenjima i animal model u kojem imamo materinski utjecaj.



Kod definiranja modela, definiramo zavisne varijable, nezavisne varijable, da bismo procijenili genetske parametre. Utjecaji u modelu koje definiramo u nezavisnim varijablama mogu biti fiksni i slučajni. Fiksni utjecaji su konstantni, dok slučajni variraju. Fiksni utjecaji se procijenjuju koristeći LS jednadžbe (*eng. least squares*) i s BLUE procjenom (REML), dok se slučajni utjecaji procijenjuju BLUP procjenom. BLUP (*eng. best linear unbiased prediction*) je nepristrana procjena slučajnih utjecaja (npr. količina mlijeka, visina, težina, veličina legla i sl.) u mješovitom modelu uz istovremenu procjenu fiksnih (sistematskih) utjecaja, često okolišni uvjeti npr. sezona, godina, farma ili njihove interakcije. Oni utječu na varijabilnost određenog svojstva koje se promatra (Henderson, 1975).

Za procjenu uzgojne vrijednosti također treba znati genetske parametre varijance i kovarijance slučajnih utjecaja, ili heritabilitete te aditivne genetske i okolišne korelacije. Ako nisu poznate, treba ih procijeniti iz podataka. One se mogu procijeniti pomoću nekoliko metoda: metodom najmanjih kvadrata (*eng. least squares*), metodom vjerojatnosti (*eng. likelihood*) u koju spadaju ML (*eng. maximum likelihood*) i REML (*eng. restricted maximum likelihood*) i Bayesovom metodom (*eng. Gibbs sampling*). U model treba uključiti i matricu srodnosti, jer postoji srodnost između životinja, tj. postoji veza između razina slučajnog utjecaja (Henderson, 1975).

U animal modelu slučajni utjecaj koji nas zanima jest aditivna genetska vrijednost životinje. Prema tome, jednostavni oblik ovog modela zapisujemo na ovaj način:

$$y_i = \mu + a_i + e_i,$$

gdje je  $y_i$  fenotipska vrijednost jedinke  $i$ ,  $\mu$  prosjek populacije,  $a_i$  je aditivna genetska vrijednost jedinke  $i$ , i  $e_i$  slučajna greška. Kod svih mješovitih modela, za svaki slučajni utjecaj pretpostavlja se da potječe od posebne raspodjele s prosjekom populacije 0 i s nepoznatim varijancama (Meyer, 1989).

Matrični zapis animal modela izgleda ovako:

$$y = X\beta + Za + e,$$

gdje je  $y$  vektor observacija za sve jedinke,  $\beta$  predstavlja vektor fiksnih utjecaja,  $X$  i  $Z$  su matrice oblika i  $e$  predstavlja vektor greške (Meyer, 1989).

Ako imamo ponovljena mjerenja po istoj životinji tada govorimo o modelu s ponovljenim mjerenjima. U tom modelu varijanca je djelom genetska, a djelom zbog istih okolišnih čimbenika, odnosno stalnog okoliša koji podrazumijeva utjecaj same životinje. Henderson (1975) je opisao model s ponavljajućim mjerenjima.

Matrični zapis animal model s ponovljenim mjerenjima izgleda ovako:

$$y = X\beta + Za + Wpe + \varepsilon$$

Gdje je  $y$  vektor opažanja,  $\beta$  vektor fiksnih utjecaja,  $a$  vektor aditivnih genetskih utjecaja,  $pe$  vektor utjecaja stalnog okoliša i  $e$  predstavlja vektor promjenjivog okoliša, tj. slučajnih greški.  $X$ ,  $Z$  i  $W$  predstavljaju matrice za gore navedene utjecaje.

Utjecaj okoliša  $e$  u ovom se modelu dijeli na stalan i promjenjiv okoliš ( $e = e_{pe} + e_p$ ). Prema tome, fenotipska se varijanca sastoji od genetske (aditivne i ne-aditivne) varijance, varijance stalnog okoliša i varijance promjenjivog okoliša. Ponovljivost predstavlja proporciju varijabilnosti utjecaja kojih djeluju stalno na životinju u odnosu na ukupnu varijabilnost (Falconer i Mackay, 1996; Mrode, 2005).

## 5. Materijali i metode

Istarske ovce se uzgajaju na farmama na kojima se tijekom zimskim mjeseci, većinom primjenjuje držanje ovaca u štali do pojave prve vegetacije početkom ožujka, nakon koje se ovce napasuju na livadama do listopada/studenoga. Proizvodnja mlijeka je sezonska budući da su ovce sezonski poliestrične životinje. Janjenje se često odvija tijekom druge polovice prosinca, dok neki uzgajivači preferiraju početak janjenja s početkom rasta vegetacije u ožujku. Razdoblje sisanja (ovisno o namjeni) traje između 30 i 60 dana, a nekada i duže ukoliko se janjad ne koristi isključivo za proizvodnju mesa. Nakon odbića (u dobi između 30 i 60 dana) istarske se ovce muzu dva puta dnevno ručnom ili strojnom mužnjom i često mužnja traje do sredine kolovoza, ovisno o dostupnosti vode tijekom ljeta (Šalamon, 2013).

### 5.1. Opis i čišćenje pedigrea

Originalni pedigree istarske ovce za ovaj diplomski rad ustupila je Hrvatska poljoprivredna agencija (HPA) koji je imao 24 219 jedinki. Nakon čišćenja duplikata i nelogičnih vrijednosti pedigrea je imao 21 628 jedinki kroz 9 generacija, što prikazuje tablica 5.1.

Tablica 5.1. Prikaz broja istarske ovce po generacijama u pedigreu

GENERACIJA	FREKVENCIJA
0	1710
1	2781
2	3438
3	2886
4	3310
5	3408
6	2647
7	1236
8	201
9	11
ukupno	21628

Pod kontrolom logičnosti/nelogičnosti misli se na to da životinja nije sama sebi otac ili majka, da otac i majka nemaju isti ID, da otac nije muškog spola, majka ženskog spola, da roditelji u trenutku početka laktacije nisu mlađi od 12 mjeseci. U genetskim modelima ne mogu biti iskorištene sve veze iz tog pedigrea tako da će se u obzir uzeti samo 4 zadnje generacije i

njihovi preci u proteklim generacijama (eng. „*trimmed pedigree*“). Nakon toga ostalo je 7491 rekorda. Detaljniji opis prikazan je u tablici 5.2.


Tablica 5.2. Karakteristike pedigreea istarske ovce sa 7491 jedinki

	Broj jedniki u rodoslovlju	Zasnivači (founder)	Jedinke s potomstvom	Jedinke bez potomaka
Broj ovnova	1722	59	326	1396
Broj ovaca	5769	708	3553	2216
Ukupno	7491	767	3879	3612

## 5.2. Opis i čišćenje podataka

Oblik vimena istarske ovce je mjereno na 11 komercijalnih farmi na području Istre tri puta tijekom laktacije. Rano laktacijska mjerenja napravljena su tokom prva tri mjeseca laktacije, srednje laktacijska mjerenja tokom četvrtog i petog mjeseca, a kasno laktacijska mjerenja od šestog do osmog mjeseca laktacije. Na šest farmi je primjenjivana ručna, a na pet farmi strojna mužnja (Šalamon, 2013).

Vanjski oblik vimena mjereno je koristeći program Image Tool s digitalnih fotografija posteriornog pogleda na vime prije mužnje. Prikupljene su izmjere maksimalne širine vimena (Mw), pune visine vimena (Fh), kuta koji sisa zatvara s vertikalnom osi vimena (Alfa) lijeve i desne strane i cisternalnog dijela vimena koji se nalazi ispod otvora sisinog kanalića (Cis) (Šalamon i Džidić, 2014) (Slika 5.1.).



Izvor: Šalamon, 2013.

Slika 5.1. Mjerenja oblika vimena istarske ovce Puna visina vimena (Fh), maksimalna širina vimena (Mw), dio lijeve (Cl) i desne (Cr) cisterne, kut lijeve strane (Alpha-l), kut desne strane (Alpha-r).

Da bismo procijenili genetske parametre bilo je potrebno analizirati kvalitetu podataka što je jedan od ciljeva ovog diplomskog rada. Podaci su analizirani opisnom statistikom numerički i grafički, kako bi se vidjela njihova raspodjela i vidjelo da li je ona normalna ili nije. To možemo vidjeti prema grafovima ostataka i ekstremnih vrijednosti, te prema usporedbi histograma s normalnom krivuljom, a testirati možemo provjerama normalnosti. Čišćenje podataka izvršeno je u tri koraka. Prvo su uklonjene vrijednosti koje su očito nelogične i pogreška samog mjerenja, s obzirom na literaturne vrijednosti za ove podatke. Nakon toga su provjerene normalnosti podataka i eventualne potrebne transformacije, te su uklonjene vrijednosti koje odstupaju za više od 1.5 interkvartilnog razmaka od prvog i trećeg kvartila po svakoj varijabli. Nakon toga su podaci analizirani mješovitim modelom koji uključuje sve fiksne utjecaje koje ćemo kasnije koristiti u animal modelu, te su prema tome izbačene sve vrijednosti sa RStudent ostacima većim od 2 ili manjim od -2.

U statistici, vrijednosti koje odstupaju (razlikuju se) od ostalih vrijednosti zovu se netipične ili ekstremne vrijednosti (*eng. outliers*). Ekstremne vrijednosti se mogu pojaviti slučajno u bilo kojoj distribuciji, i najčešće indiciraju pogreške u mjerenju ili da populacija ima puno rubnih vrijednosti. Ekstremne vrijednosti se trebaju detektirati, analizom ekstremnih vrijednosti u ovisnosti o definiranim fiksnim utjecajima, blokova i tretmana. Ekstremne vrijednosti mogu ukazivati na pogrešne podatke i procedure, ili na područja u kojima određena teorija neće biti točna. Podaci će se prikazati i analizirati pomoću nekoliko procedura u SAS-u: procedurom TRANSREG, REG, GLM, SGPlot, UNIVARIATE i MEANS. Analizirala su se mjerenja


oblika vimena istarske ovce za visinu (Fh) i širinu (Mw) vimena, za visinu cisterne ispod sisnog kanalića (Cis) i kut koji sisa zatvara s okomicom vimena (Alfa). Procedurom TRANSREG je pomognuto da se analiza varijance za blok varijable napravi s pristupom regresije. Dalje je napravljena procedura REG, koja procijenjuje koeficijente regresije i njezine standarne greške, a također se dobiva i procjena ostataka. Neke od procjena ostataka koje su napravljene za svaku varijablu su studentova (*eng. Rstudent by leverage*) i Cook-ova (*eng. Cook's D*) procjena. Studentova procjena ostataka procijenjuje ostatke na principu standardnih devijacija, a Cook-ova mjeri utjecajne točke (*eng. „influence points“*).

Na slikama 5.2. do 5.5. prikazana je dijagnostika ekstremnih vrijednosti za visinu i širinu vimena, za visinu cisterne ispod sisnog kanalića i kut koji sisa zatvara s okomicom vimena nakon uklanjanja nelogičnih vrijednosti, a prije čišćenja na ekstremne vrijednosti vrijednosti i analize fiksnih utjecaja. Ekstremne vrijednosti su označeni narančastom bojom. Njih je lako detektirati na grafu jer se nalaze na određenoj udaljenosti („izvan“) od skupa koji sadrži većinu točaka. Kada bi kroz skup točaka označen plavom bojom povukli pravac koji bi bio „os simetrije“ tog skupa, točke označene narančastom bojom su na velikoj udaljenosti od tog pravca. Ta udaljenost se naziva ostatak. Na slikama 5.10. do 5.13. prikazana je normalnost tih ostataka. Točke označene zelenom bojom su točke čija se vrijednost po x osi nalazi van danog intervala i zovu se potencijalne vrijednosti prevage (*eng. leverage*), a smeđom bojom su one koje su i ekstremne vrijednosti i potencijalne vrijednosti prevage. Te točke mogu imati jaki i slabi utjecaj na regresijski pravac. Zato u analizama regresije moramo pažljivo gledati na točke koje utječu na model, tj. njegovu stabilnost. Ako se točka nalazi izvan intervala x osi, a jako je udaljena od ostalih točaka i ne ide u njihovom smjeru govorimo o točki s jakim utjecajem na regresiju.



Slika 5.2. Dijagnostika ekstremnih vrijednosti za širinu vimena ( $M_w$ )


U ovom grafikonu prikazani su Rstudent ostaci za vrijednosti širine vimena (Mw) na y osi od -3 do 3, a na x osi su prikazane potencijalne vrijednosti prevage od 0.00 do 0.5. Točke označene zelenom bojom su potencijalne vrijednosti prevage, jer se njihova vrijednost po x osi nalazi van danog intervala koji je u ovom slučaju od 0.00 do 0.85. Točke označene crvenom bojom su ekstremne vrijednosti, jer gledano po y osi njihova vrijednost se nalazi van danog intervala koji je u tom slučaju od -2 do 2. Sve ove ekstremne vrijednosti za Mw koje su ostale nakon čišćenja ne bi mijenjale pravac regresije u tolikoj mjeri da ih se treba ukloniti, pa ih možemo smatrati odstupanjima sa slabim utjecajem. Opažanja 198 i 199 jako odstupaju u odnosu na x os i trebalo bi ih daljnje razmotriti.



Slika 5.3. Dijagnostika ekstremnih vrijednosti za visinu cisterne ispod sisnog kanalića (Cis)

U ovom grafikonu prikazani su Rstudent ostaci za vrijednosti visine cisterne vimena (Cis) na y osi od -2 do 4, a na x osi su prikazane potencijalne vrijednosti prevage od 0.00 do 0.125. Točke označene zelenom bojom su potencijalne vrijednosti prevage, jer se njihova vrijednost po x osi nalazi van danog intervala, koji je u ovom slučaju od 0.00 do 0.045. Točke označene crvenom bojom su ekstremne vrijednosti, jer gledano po y osi njihova vrijednost se nalazi van danog intervala koji je u tom slučaju od -2 do 2. Sve ove ekstremne vrijednosti za Cis koje su ostale nakon čišćenja ne bi mijenjale pravac regresije u tolikoj mjeri da ih se treba ukloniti, pa ih možemo smatrati odstupanjima sa slabim utjecajem.






Slika 5.5. Dijagnostika ekstremnih vrijednosti za kut sise (Alfa)

U ovom grafikonu prikazani su Rstudent ostaci za vrijednosti kuta sise (Alfa) na y osi od -3 do 3, a na x osi su prikazane potencijalne vrijednosti prevage od 0.00 do 0.12. Točke označene zelenom bojom su potencijalne vrijednosti prevage, jer se njihova vrijednost po x osi nalazi van danog intervala.


Na slikama 5.6. do 5.9. prikazani su QQ plotovi ostataka za visinu i širinu vimena, za visinu cisterne ispod sisnog kanalića i kut koji sisa zatvara s okomicom vimena nakon uklanjanja nelogičnih vrijednosti, a prije čišćenja na ekstremne vrijednosti i analize fiksnih utjecaja.

QQ plotovi ostataka dobiveni su procedurom GLM. Procedura GLM provodi analizu varijance za općenite linearne modele, uključujući i one za eksperimentalni dizajn i modele sa kovarijancama. Putem procjene, procedura GLM omogućuje testiranje hipoteze za utjecaje linearnog modela. Prikazuje sumu kvadrata povezanih sa svakom hipotezom, te na zahtjev formira procijenjene funkcije u testu. QQ plotovi ostataka prikazuju kako ostaci varijable prate danu distribuciju.




Slika 5.4. QQ plot ostataka za visinu vimena (Fh)

Na slici 5.6. koja prikazuje QQ plot ostataka za visinu vimena (Fh) većina se točaka nalazi na pravcu ili dovoljno blizu pravca (točke na rubovima pravca). Kako udaljenost tih točaka od pravca nije prevelika ovaj graf pokazuje dobru razdiobu ostataka i kvantila, također linija ostataka ide putem ravnog pravca te to ukazuje da su ostaci normalno raspoređeni.




Slika 5.5. QQ plot ostataka za širinu vimena (Mw)

Na slici 5.7. koja prikazuje QQ plot ostataka za širinu vimena (Mw) većina se točaka nalazi na pravcu ili dovoljno blizu pravca (točke na rubovima pravca). Kako udaljenost tih točaka od pravca nije prevelika ovaj graf pokazuje dobru razdiobu ostataka i kvantila, također linija ostataka ide putem ravnog pravca te to ukazuje da su ostaci normalno raspoređeni.



Slika 5.6. QQ plot ostataka za visinu cisterne ispod sisnog kanalića (Cis)


Na slici 5.8. koja prikazuje QQ plot ostataka za visinu cisterne ispod sisnog kanalića (Cis) većina se točaka nalazi na pravcu ili dovoljno blizu pravca (točke na rubovima pravca). Kako udaljenost tih točaka od pravca nije prevelika ovaj graf pokazuje dobru razdiobu ostataka i kvantila, također linija ostataka ide putem ravnog pravca te to ukazuje da su ostaci normalno raspoređeni.



Slika 5.7. QQ plot ostataka za kut sise (Alfa)


Na slici 5.9. koja prikazuje QQ plot ostataka za kut sise (Alfa) većina se točaka nalazi na pravcu ili dovoljno blizu pravca (točke na rubovima pravca). Kako udaljenost tih točaka od pravca nije prevelika ovaj graf pokazuje dobru razdiobu ostataka i kvantila, također linija ostataka ide putem ravnog pravca te to ukazuje da su ostaci normalno raspoređeni.

Na slikama 5.10. do 5.13. prikazana je normalnost ostataka za visinu i širinu vimena, za visinu cisterne ispod sisnog kanalića i kut koji sisa zatvara s okomicom vimena nakon uklanjanja nelogičnih vrijednosti, a prije čišćenja na ekstremne vrijednosti i analize fiksnih utjecaja.




Slika 5.8. Normalnost ostataka za visinu vimena (Fh)

Na slici 5.10. Empirijska raspodjela za ostatke varijable mjerenja pune visine vimena (Fh) gotovo se poklapa s normalnom krivuljom. Prema tome može se reći da je raspodjela podataka normalna, te da nema mnogo ekstremnih odstupanja.




Slika 5.9. Normalnost ostataka za širinu vimena (Mw)

Na slici 5.11. Empirijska raspodjela za ostatke varijable mjerenja maksimalne širine vimena ( $M_w$ ) gotovo se poklapa s normalnom krivuljom. Prema tome može se reći da je raspodjela podataka normalna, te da nema mnogo ekstremnih odstupanja.



Slika 5.10. Normalnost ostataka za visinu cisterne ispod sisnog kanalića (Cis)


Na slici 5.12. Empirijska raspodjela za ostatke varijable mjerenja visinu cisterne ispod sisnog kanalića (Cis) gotovo se poklapa s normalnom krivuljom. Postoji nagnutost krivulje zato što je minimum pri mjerenjima 0.



Slika 5.11. Normalnost ostataka za kut sise (Alfa)

Na slici 5.13. Empirijska raspodjela za ostatke varijable kuta sise (Alfa), gotovo se poklapa s normalnom krivuljom. Prema tome može se reći da je raspodjela podataka normalna, te da nema mnogo ekstremnih odstupanja.


Na slikama 5.14. do 5.17. prikazan je histogram s Empirijskom raspodjelom za visinu i širinu vimena, za visinu cisterne ispod sisnog kanalića i kut koji sisa zatvara s okomicom vimena.



Slika 5.12. Histogram s empirijskom raspodjelom za visinu vimena (Fh)

N – broj opažanja; MEAN – prosjek; MIN – minimum; MAX – maksimum


Slika 5.14. prikazuje histogram s empirijskom raspodjelom za visinu vimena (Fh). Možemo vidjeti da je bilo 506 opažanja. Prosjek je 13.4. Na slici možemo vidjeti da je najveća frekvencija oko prosjeka. Empirijska raspodjela se uglavnom poklapa s normalnom Gaussovom krivuljom imožemo zaključiti da je distribucija normalna.



Slika 5.13. Histogram s empirijskom raspodjelom za širinu vimena (Mw)

N – broj opažanja; MEAN – prosjek; MIN – minimum; MAX – maksimum


Slika 5.15. prikazuje histogram s empirijskom raspodjelom za maksimalnu širinu vimena (Mw). Možemo vidjeti da je bilo 470 opažanja. Prosjek je 10.5. Na slici možemo vidjeti da je najveća frekvencija oko prosjeka. Empirijska raspodjela se uglavnom poklapa s normalnom Gaussovom krivuljom i možemo zaključiti da je distribucija normalna.



Slika 5.14. Histogram empirijskom raspodjelom za visinu cisterne ispod sisnog kanalića (Cis)

N – broj opažanja; MEAN – prosjek; MIN – minimum; MAX – maksimum

Slika 5.16. prikazuje histogram s empirijskom raspodjelom za visinu cisterne ispod sisnog kanalića (Cis). Možemo vidjeti da je bilo 862 opažanja. Prosjek je 1.26. Na slici možemo vidjeti da je najveća frekvencija oko prosjeka. Zbog minimuma mjerenja 0.0 i toga što vrijednosti nisu negativne postoji nagnutost krivulje. Empirijska raspodjela se uglavnom poklapa s normalnom Gaussovom krivuljom što nam govori da je raspodjela normalna i da nema odstupanja.



Slika 5.17. Histogram s empirijskom raspodjelom za kut sise vimena (Alfa)

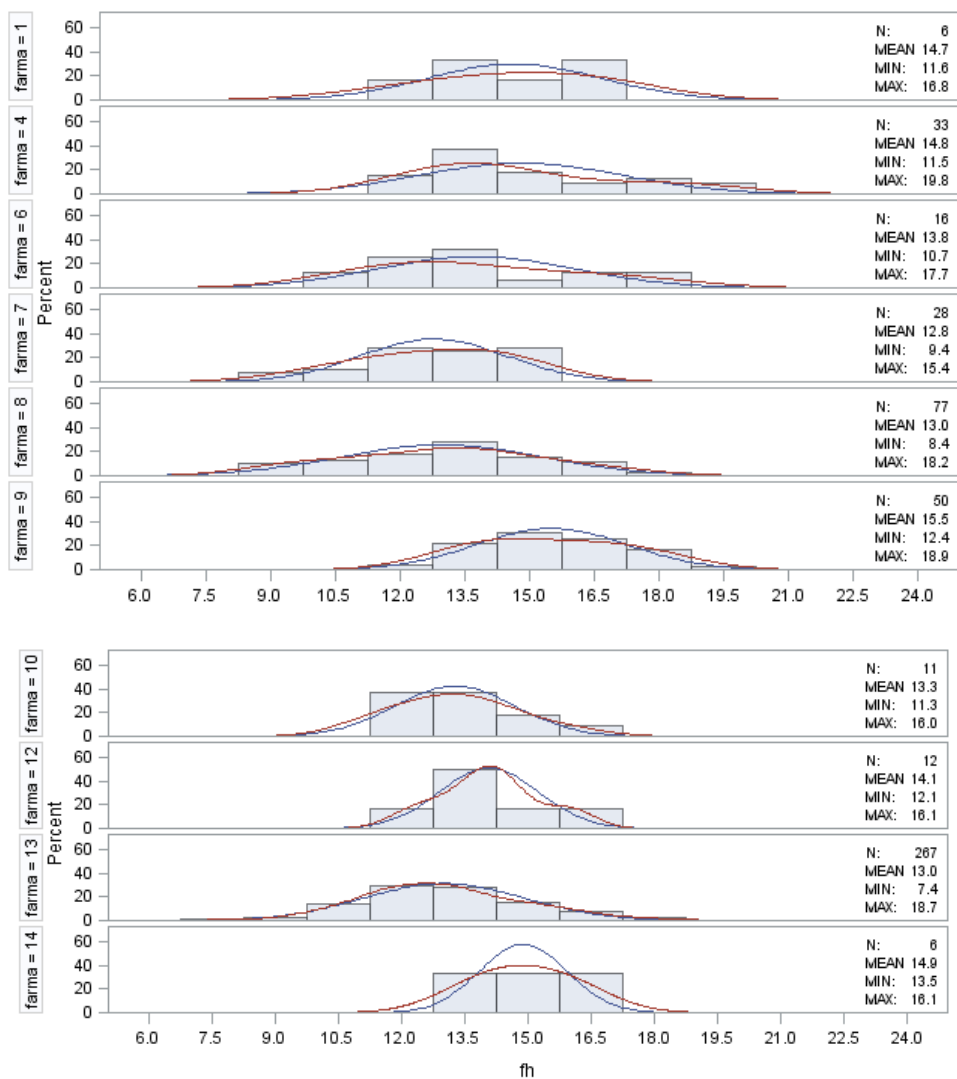
N – broj opažanja; MEAN – prosjek; MIN – minimum; MAX – maksimum

Slika 5.17. prikazuje histogram s empirijskom raspodjelom za kut sise (Alfa). Možemo vidjeti da je bilo 848 opažanja. Prosjek je 37.6. Na slici možemo vidjeti da je najveća frekvencija oko prosjeka. Empirijska raspodjela se uglavnom poklapa s normalnom Gaussovom krivuljom i možemo zaključiti da je distribucija normalna.

### 5.3. Opis i raspodjela mjerenja pune visine vimena (Fh)

U početnim podacima za mjerenja pune visine vimena (Fh) ukupno je bilo 617 opažanja i 255 životinje. Nakon čišćenja nepravilnosti odnosno izbacivanja onih ovaca koje nemaju minimalno 2 mjerenja po laktaciji ukupno je ostalo 161 životinje i 560 opažanja. Provedene su procedure TRANSREG, REG, GLM, UNIVARIATE i pokazalo se da ima odstupanja i da se podaci moraju očistiti kako procjena ne bi bila pogrešna. Nakon čišćenja ekstremnih vrijednosti, te ovaca što nemaju minimalno 2 mjerenja ukupno je ostalo 506 opažanja. Tih 506 opažanja raspoređeno je na 10 farmi. U prvom mjerenju broj opažanja bio je 181, u drugom 175, a u trećem 150. Mjerenja su se uzimala u travnju i prosincu. Provedena je ponovo procedura UNIVARIATE. Također je provedena procedura MEANS. Raspodjela mjerenja Fh po farmama, laktacijama, mjerenjima prikazuju slike 5.18. do 5.20.






Slika 5.15. Raspodjela mjerenja visine vimena (Fh) po farmama

N – broj opažanja; MIN – minimum; MAX – maksimum


Na slici 5.18. koja prikazuje raspodjelu mjerenja visine vimena (Fh) po farmama možemo vidjeti da se empirijska raspodjela relativno poklapa sa normalnom. Najmanji broj opažanja (N) imaju prva i četrnaesta farma sa samo 6 opažanja, dok na trinaestoj farmi imamo najveći broj opažanja (N) sa 267 opažanja. Najveća frekvencija je oko prosjeka. Možemo zaključiti da je raspodjela normalna i da nema odstupanja.



Slika 5.16. Raspodjela mjerenja visine vimena (Fh) po laktacijama

N – broj opažanja; MEAN – prosjek; MIN – minimum; MAX – maksimum

Na slici 5.19. koja prikazuje raspodjelu mjerenja visine vimena (Fh) po laktacijama možemo vidjeti da se empirijska raspodjela relativno poklapa sa normalnom. Najmanji broj opažanja (N) je u trećoj laktaciji sa 57 opažanja, dok je u drugoj laktaciji najveći broj opažanja (N) sa 140 opažanja. Najveća frekvencija je oko prosjeka. Možemo zaključiti da je raspodjela normalna i da nema odstupanja.




Slika 5.17. Raspodjela mjerenja visine vimena (Fh) po mjerenjima


N – broj opažanja; MEAN – prosjek; MIN – minimum; MAX – maksimum

Na slici 5.20. koja prikazuje raspodjelu mjerenja visine vimena (Fh) po mjerenjima možemo vidjeti da se empirijska raspodjela relativno poklapa sa normalnom. Najmanji broj opažanja (N) je u trećem, a najveći u prvom mjerenju. Najveća frekvencija je oko prosjeka. Prosjek se kreće od 12.8 u trećem, 13.8 u drugom i 13.6 u prvom mjerenju. Možemo zaključiti da je raspodjela normalna i da nema odstupanja.

## 5.4. Opis i raspodjela mjerenja maksimalne širine vimena (Mw)

U početnim podacima za mjerenja maksimalne širine vimena (Mw) ukupno je bilo 590 opažanja i 247 životinje. Nakon čišćenja nepravilnosti odnosno izbacivanja onih što nemaju minimalno 2 mjerenja po laktaciji ukupno je ostalo 149 životinje i 532 opažanja. Provedene su procedure TRANSREG, REG, GLM, UNIVARIATE i pokazalo se da ima odstupanja i da se podaci moraju očistiti kako procjena ne bi bila pogrešna. Nakon čišćenja ekstremnih vrijednosti, te ovaca što nemaju minimalno 2 mjerenja ukupno je ostalo 470 opažanja. Tih 470 opažanja raspoređeno je na 10 farmi. U prvom mjerenju broj opažanja bio je 166, u drugom 169, a u trećem 135. Mjerenja su se uzimala u travnju i prosincu. Provedena je ponovo procedura UNIVARIATE. Također je provedena procedura MEANS. Raspodjela mjerenja Mw po farmama, laktacijama, mjerenjima prikazuju slike 5.21. do 5.23.






Slika 5.18. Raspodjela mjerenja širine vimena (Mw) po farmama

N – broj opažanja; MIN – minimum; MAX – maksimum


Na slici 5.21. koja prikazuje raspodjelu mjerenja širine vimena (Mw) po farmama možemo vidjeti da se empirijska raspodjela relativno poklapa sa normalnom krivuljom. Najmanji broj opažanja (N) je u prvoj farmi sa samo 2 opažanja, dok je u trinaestoj farmi najveći broj opažanja (N) sa 253 opažanja. Najveća frekvencija je oko prosjeka. Možemo zaključiti da je raspodjela normalna i da nema odstupanja.



Slika 5.19. Raspodjela mjerenja širine vimena (Mw) po laktacijama

N – broj opažanja; MEAN – prosjek; MIN – minimum; MAX – maksimum

Na slici 5.22. koja prikazuje raspodjelu mjerenja širine vimena (Mw) po laktacijama možemo vidjeti da se empirijska raspodjela relativno poklapa sa normalnom i možemo zaključiti da je raspodjela normalna i da nema odstupanja, što možemo vidjeti i iz rezultata univariate procedure.



Slika 5.23. Raspodjela mjerenja širine vimena (Mw) po mjerenjima

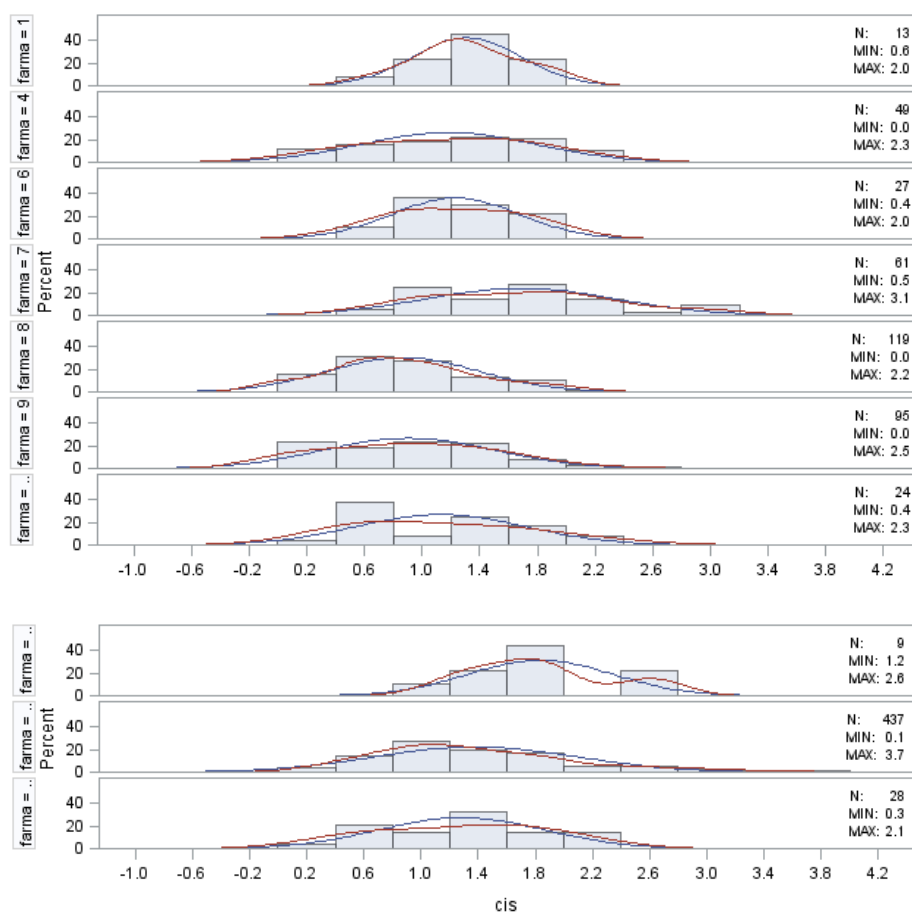
N – broj opažanja; MEAN – prosjek; MIN – minimum; MAX – maksimum

Na slici 5.23. koja prikazuje raspodjelu mjerenja širine vimena (Mw) po mjerenjima možemo vidjeti da se empirijska raspodjela relativno poklapa sa normalnom i možemo zaključiti da je raspodjela normalna i da nema odstupanja, što možemo vidjeti i iz univariate procedure.

## 5.5. Opis i raspodjela mjerenja visine cisterne koja se nalazi ispod otvora sisnog kanalića (Cis)

U početnim podacima za mjerenja visine cisterne koja se nalazi ispod otvora sisnog kanalića (Cis) ukupno je bilo 1033 opažanja i 240 životinje. Nakon čišćenja nepravilnosti odnosno izbacivanja onih što nemaju minimalno 2 mjerenja po laktaciji ukupno je ostalo 142 životinje i 925 opažanja. Provedene su procedure TRANSREG, REG, GLM, UNIVARIATE i pokazalo se da ima odstupanja i da se podaci moraju očistiti kako procjena ne bi bila pogrešna. Nakon čišćenja ekstremnih vrijednosti, te ovaca što nemaju minimalno 2 mjerenja ukupno je ostalo 862 opažanja. Tih 862 opažanja raspoređeno je na 10 farmi. U prvom mjeranju broj opažanja bio je 286, u drugom 342, a u trećem 234. Mjerenja su se uzimala u travnju i prosincu.


Provedena je ponovo procedura UNIVARIATE. Također je provedena procedura MEANS. Raspodjela mjerenja Cis po farmama, laktacijama, mjerenjima prikazuju slike 5.24. do 5.26.



Slika 5.24. Raspodjela mjerenja visine cisterne ispod sisnog kanalića (Cis) po farmama

N – broj opažanja; MIN – minimum; MAX – maksimum


Na slici 5.24. koja prikazuje raspodjelu mjerenja visine cisterne ispod sisnog kanalića (Cis) po farmama možemo vidjeti da se empirijska raspodjela relativno poklapa sa normalnom i možemo zaključiti da je raspodjela normalna i da nema odstupanja, što možemo vidjeti i iz rezultata univariate procedure.



Slika 5.20. Raspodjela mjerenja visine cisterne ispod sisnog kanalića (Cis) po laktacijama

N – broj opažanja; MEAN – prosjek; MIN – minimum; MAX – maksimum

Na slici 5.25. koja prikazuje raspodjelu mjerenja visine cisterne ispod sisnog kanalića (Cis) po laktacijama možemo vidjeti da se empirijska raspodjela relativno poklapa sa normalnom i možemo zaključiti da je raspodjela normalna i da nema odstupanja, što možemo vidjeti i iz rezultata univariate procedure.




Slika 5.26. Raspodjela mjerenja visine cisterne ispod sisnog kanalića (Cis) po mjerenjima

N – broj opažanja; MEAN – prosjek; MIN – minimum; MAX – maksimum


Na slici 5.26. koja prikazuje raspodjelu mjerenja visine cisterne ispod sisnog kanalića (Cis) po mjerenjima možemo vidjeti podstrukturu u trećem mjerenju. U prva dva mjerenje možemo vidjeti da se empirijska raspodjela relativno poklapa sa normalnom i možemo zaključiti da je raspodjela normalna i da nema odstupanja, što možemo vidjeti i iz rezultata univariate procedure.

## 5.6. Opis i raspodjela mjerenja kuta sise (Alfa)

U podacima za kut koji sisa zatvara s vertikalnom osi vimena (Alfa) ukupno je bilo 1023 opažanja i 242 životinje. Nakon čišćenja nepravilnosti odnosno izbacivanja onih što nemaju minimalno 2 mjerenja po laktaciji ukupno je ostalo 144 životinje i 917 opažanja. Provedene su procedure TRANSREG, REG, GLM, UNIVARIATE i pokazalo se da ima odstupanja i da se podaci moraju očistiti kako procjena ne bi bila pogrešna. Nakon čišćenja ekstremnih vrijednosti, te ovaca što nemaju minimalno 2 mjerenja ukupno je ostalo 848 opažanja. Tih 848 opažanja raspoređeno je na 10 farmi. U prvom mjerenju broj opažanja bio je 281, u drugom 338, a u trećem 229. Mjerenja su se uzimala u travnju i prosincu. Provedena je ponovo procedura UNIVARIATE. Također je provedena procedura MEANS. Raspodjela mjerenja Alfa po farmama, laktacijama, mjerenjima prikazuju slike 5.27. do 5.29.








Slika 5.27. Raspodjela mjerenja kuta koji sisa zatvara s okomicom vimena (Alfa) po farmama

N – broj opažanja; MIN – minimum; MAX – maksimum


Na slici 5.27. koja prikazuje raspodjelu mjerenja kuta koji sisa zatvara s okomicom vimena (Alfa) po farmama možemo vidjeti da se empirijska raspodjela relativno poklapa sa normalnom i možemo zaključiti da je raspodjela normalna i da nema odstupanja, što možemo vidjeti i iz univariate procedure.



Slika 5.21. Raspodjela mjerenja kuta koji sisa zatvara s okomicom vimena (Alfa) po laktacijama

N – broj opažanja; MEAN – prosjek; MIN – minimum; MAX – maksimum

Na slici 5.28. koja prikazuje raspodjelu mjerenja kuta sise (Alfa) po laktacijama možemo vidjeti da se empirijska raspodjela relativno poklapa sa normalnom i možemo zaključiti da je raspodjela normalna i da nema odstupanja, što možemo vidjeti i iz univariate procedure.



Slika 5.22. Raspodjela mjerenja kuta koji sisa zatvara s okomicom vimena (Alfa) po mjerenjima  
N – broj opažanja; MEAN – prosjek; MIN – minimum; MAX – maksimum

Na slici 5.29. koja prikazuje raspodjelu mjerenja kuta koji sisa zatvara s okomicom vimena (Alfa) po mjerenjima možemo vidjeti da se empirijska raspodjela relativno poklapa sa normalnom i možemo zaključiti da je raspodjela normalna i da nema odstupanja, što možemo vidjeti i iz univariate procedure.

Ako gledamo distribuciju podataka po kategorijama možemo reći da je varijabla Cis po svim kategorijama uglavnom imala normalnu raspodjelu. Za varijablu Mw po kategorijama distribucija je uglavnom bila normalna. Normalna distribucija varijable nije zabilježena u drugoj, četvrtoj i šestoj laktaciji, zatim u kategoriji mjeseca janjenja, koja obuhvaća 11 i 12 mjesec, te u prvom i drugom mjeranju. Za varijablu Fh po kategorijama distribucija je također bila uglavnom normalna, ali je provjera normalnosti pokazala odstupanje od normalne distribucije za ovu varijablu u prvom mjeranju, farmi 13 i mjesecu 11 i 12.

Tablica 5.3. Opisna statistika za varijable koje će se kasnije koristiti u izgradnji modela

	Opažanja	Prosjek	St.devijacija	St.greška	Prosjek broja laktacije	Prosjek mjerenja
Fh	506	13.45	2.15	0.10	3.20	1.94
Mw	470	10.51	1.96	0.09	3.19	1.93
Cis	862	1.26	0.69	0.02	3.14	1.94
Alfa	848	37.61	13.31	0.46	3.20	1.94

## 6. Modeli za procjenu genetskih parametara

Za procjenu genetskih parametara bitno je definirati optimalni model proučavanjem fiksnih efekata. Analiza ekstrema u ovisnosti o definiranim fiksnim utjecajima vršit će se procedurom MIXED u SAS 9.4 statističkom programu. Za procjenu genetskih parametara koristit će se animal model u SAS-u u kojem će farma, broj i stadij laktacije, mjerenje i mjesec biti definirani kao fiksni utjecaji, a aditivna genetska vrijednost životinje kao slučajni utjecaj. Detaljnije, fiksni utjecaji su mjerenje, tj. kada se mjerilo u laktaciji i interakcija farme, laktacije i sezone janjenja. Modeli ne konvergiraju ako je broj observacija unutar kategorija varijabli koje se koriste za fiksne utjecaje premali, pa su se za neke varijable koje se koriste za fiksne utjecaje kategorije spojile. Kako se radi o ponovljenim mjerenjima tijekom i između laktacija, aditivna genetska vrijednost ovce biti će slučajan utjecaj u mješovitom modelu. Utjecaj stalnog okoliša (*eng. permanent environment*) također će biti slučajni utjecaj, jer on uhvaća varijabilnost po jedinki koja nije genetska niti pod utjecajem nekih od faktora.

Genetski parametri za visinu vimena (Fh), širinu vimena (Mw), visinu cisterne ispod sisnog kanalića (Cis) i kuta koji sisa zatvara s okomicom vimena (Alfa) procijenjeni su mješovitim animalnim model s matricom kovarijanci (Formula 1; Formula 2).

Formula 1:

$$y_{flkmn} = \mu + D_m + V_f * L_l * S_k + a_n + pe_n + e_{flkmn}$$

Gdje je:

$Y_{flkmn}$  = observacija za Fh, Mw, Cis, Alfa

$D_m$  = fiksni utjecaj mjerenja u laktaciji ( $m = 1, 2$  i  $3$ ; klaster mjerenja u laktaciji)

$V_f$  = fiksni utjecaj za farmu ( $f$  = klaster farme; radi sličnog prosjeka i premalog broja opažanja spojene u finalne tri razine)

$L_l$  = fiksni utjecaj za redni broj laktacije ( $l = 1 - 5$ ; klaster rednog broja laktacije; laktacija 5 i 6 spojena u jednu zbog malog broja opažanja i sličnih prosjeka )

$S_k$  = fiksni utjecaj za mjesec janjenja u sezoni ( $k$  = klaster mjeseca janjenja; dvije razine: 1112 obuhvaća zimska janjenja i 123 koji obuhvaća proljetna janjenja )

$a_n$  = slučajni aditivni utjecaj životinje ( $n$  (Fh) = 506,  $n$  (Mw) = 470,  $n$  (Cis) = 862,  $n$  (Alfa) = 848)

$pe_n$  = slučajni utjecaj okoliša u danu mjerenja (životinje koje imaju ponovljena mjerenja)

$$e_{fklmn} = \text{ostatak}$$

Modelom formule 2 su analizirani podaci podselektirani za mjerenje sredinom laktacije (mjerenje 2) za navedene varijable, s obzirom na najveći broj izmjera u toj kategoriji.

Formula 2:

$$y_{flkn} = \mu + V_f * L_l * S_k + a_n + e_{flkn}$$

Gdje je:

$Y_{flkn}$  = observacija za Fh, Mw, Cis

$V_f$  = fiksni utjecaj za farmu (f = klaster farme; radi sličnog prosjeka i premalog broja opažanja spojene u finalne tri razine)

$L_l$  = fiksni utjecaj za redni broj laktacije (l = 1 – 5; klaster rednog broja laktacije; laktacija 5 i 6 spojena u jednu zbog malog broja opažanja i sličnih prosjeka )

$S_k$  = fiksni utjecaj za mjesec janjenja u sezoni (k = klaster mjeseca janjenja; dvije razine: 1112 obuhvaća zimska janjenja i 123 koji obuhvaća proljetna janjenja )

$a_n$  = slučajni aditivni utjecaj životinje (n (Cis) = 344, n (Fh) = 179 , n (Mw) = 31)

$e_{fkln}$  = ostatak

Varijance koje su procijenjene ovim modelima su:

- komponenta aditivne genetske varijance  $V_a$
- komponenta varijance stalnog okoliša  $V_{pe}^*$
- komponenta ostatka varijance  $V_r$
- komponenta individualne varijance  $V_i^* = V_a + V_{pe} + V_r$
- komponenta fenotipske varijance  $V_p$

Ponovljivost (r) je proporcija  $V_i$  i  $V_p$ , a heritabilitet u užem smislu ( $h^2$ ) je proporcija  $V_a$  i  $V_p$ . Ponovljivost između laktacija je izračunata kao omjer kovarijance između mjerenja koji djeluju stalno i ukupne varijabilnosti.

U oba modela primjenjena matrica kovarijanci životinja temeljem pedigreea dobivena je procedurom inbreed u statističkom paketu SAS, te je u mješoviti model uvrštena podselekcija iz matrice dobivene za 7491 rekorda u pedigreeu, koja se odnosi samo na one životinje za koje su izvršena mjerenja.

## 7. Rezultati

### 7.1. Genetske analize svojstva oblika vimena istarske ovce

Genetske parametre svojstva oblika vimena prikazuje tablica 7.1. Ponovljivost je 0.43 za Alfū. Heritabiliteti iznose 0.05 za Alfū i 0.71 za Cis. Heritabiliteti za Fh i Mw nisu računati, jer ni Formulom 1 ni uz redukciju podataka na mjerenje sredinom laktacije i primjenom Formule 2, kao u slučaju procjena za Cis, nije procijenjen značajan aditivni utjecaj. (standardna greška (Fh) = 0.67; standardna greška (Mw) = 0.37). Formulom 1 nije procijenjen značajan aditivni utjecaj za Cis, pa su se podselektirali podaci iz drugog mjerenja koje ima najviše observacija i samim time nismo više imali utjecaj ponovljenog mjerenja (Formula 2). Time je dobiven značajan aditivni utjecaj za Cis i iznosi 0.32 ( $p = 0.01$ ).

Tablica 7.1. Komponente varijance, heritabiliteti i ponovljivost za svojstva oblika vimena

	<b>V<sub>r</sub></b>	<b>V<sub>a</sub></b>	<b>V<sub>pe</sub></b>	<b>V<sub>i</sub></b>	<b>V<sub>p</sub></b>	<b>h<sup>2</sup></b>	<b>r<sup>2</sup></b>	<b>Stand.greška</b>
<b>Cis*</b>	0.14	0.32	/	/	0.46	0.71	/	0.05
<b>Alfa**</b>	93.00	8.56	60.73	69.29	162.29	0.05	0.43	20.26

Cis - visina cisterne ispod sisnog kanalića (cm); Alfa - kut koji sisa zatvara s okomicom vimena; V<sub>a</sub> - aditivna genetska komponenta varijance; V<sub>pe</sub> - komponenta varijance stalnog okoliša; V<sub>r</sub> - komponenta ostataka varijance; V<sub>i</sub> - komponenta individualne varijance; V<sub>p</sub> - komponenta fenotipske varijance; h<sup>2</sup> - heritabilitet; r<sup>2</sup> - ponovljivost; stand.greška - standardna greška

\* procjena genetskih parametara iz formule 2; \*\* procjena genetskih parametara iz formule 1

## 8. Rasprava

Vrijednost koja je dobivena za ponovljivost (*eng. repeatability*) za kut sise (Alfa) je 0.43. Ponovljivost za visinu cisterne (Cis), punu visinu vimena (Fh) i maksimalnu dubinu (Mw) nisu računate, je su se ponovljena mjerenja izbacila u svrhu dobivanja značajne aditivna varijance. Ponovljivost kuta sise (0.43) manja je od onih dobivenih u drugim istraživanjima (Džidić i sur., 2009; Fernandez i sur., 1997; Šalamon, 2013). Fernandez i suradnici (1997) kažu da ako je za svojstva vimena ponovljivost iznad 0.5, jedno mjerenje po laktaciji bilo bi dovoljno za rješavanje osnovnih selektivnih ciljeva i kriterija, što samim time govori govori o dobroj ponovljivosti ( $r^2 \approx 1$ ). Ako je dobra ponovljivost, znači da su podaci, način mjerenja i model dobri te je potrebno manje mjerenja po laktaciji.

Dobiveni heritabiliteti za kut sise (Alfa) i visinu cisterne (Cis) iznose 0.05 i 0.71. Heritabiliteti za punu visinu vimena (Fh) i maksimalnu dubinu (Mw) nisu računati, jer procijenjena aditivna genetska varijanca nije bila značajna. Heritabiliteti za kut i visinu cisterne mogu se uzeti u obzir, jer je procjena aditivne varijance u ovom radu bila značajna ( $V_a$  (Alfa) = 8.56,  $p$  (Alfa) = 0.02;  $V_a$  (Cis) = 0.32,  $p$  (Cis) = 0.01). Heritabilitet za visinu cisterne viši je od heritabiliteta procijenjenih u drugim studijima (Fernandez i sur., 1997; Gelasaksis i sur, 2012, Legarra i Ugarte, 2005; Šalamon, 2013). Međutim, kako je navedeno u doktorskom radu Šalamon (2013) te studije nisu uključile analizu cisternalnog dijela ispod sisnog kanalića. Svojstvo koje opisuje Cis u tim studijima zapravo je rascjep vimena (*eng. udder cleft*). Heritabilitet za kut sise iznosi 0.05, što je niže od heritabiliteta dobivenih u drugim studijima (Džidić i sur., 2009; Fernandez i sur., 1997; Gelasaksis i sur, 2012, Legarra i Ugarte, 2005; Šalamon, 2013). Rezultati ovog rada daju osnovne parametre za raspravu o selektivnim ciljevima i kriterijima istarske ovce uzimajući u obzir svojstva oblika vimena. Genetski parametri dobiveni za svojstva oblika vimena pokazuju da bi visina cisterne ispod sisnog kanalića bila logičnija za selekciju od kuta koji sisa zatvara s okomicom vimena, zbog visokog heritabiliteta.

## 9. Zaključak

Nakon analiziranja podataka opisnim statističko-numeričkim i grafičkim metodama, ekstremna odstupanja su detektirana i nakon toga uklonjena kako ne bi narušila normalnost podataka, a samim time i procjenu genetskih parametara; heritabiliteta i ponovljivosti. Proveden je animal model i pokazalo se da je aditivna genetska vrijednost za kut koji sisa zatvara s okomicom vimena i visinu cisterne ispod sisnog kanalića značajna. Vrijednost za visinu cisterne kod istarske ovce mala je u odnosu na visokoselektirane pasmine ovaca, te je vrijednost za kut sise općenito manja nego u visokoselektiranih ovaca. Drugi faktor koji nam pokazuje hoće li se selekcijom na ta svojstva vidjeti napredak je heritabilitet. Po dobivenim heritabilitetima možemo zaključiti da svojstva s višim heritabilitetom reagiraju brže na selekciju, dok svojstva s nižim heritabilitetom ovise više o poboljšanju okoline, kao što je farma, mjerenje u danu laktacije i sezona kad je mjerenje obavljeno. Kako je aditivni dio genotipa funkcija gena dobivenih od roditelja, to je najčešće dio genotipa na koji se može vršiti selekcija i stoga je od primarnog interesa. S druge strane, procijenjene aditivne genetske vrijednosti za punu visinu i maksimalnu širinu vimena nisu bile značajne, što vjerojatno proizlazi iz nedovoljne količine podataka za ta svojstva i nedovoljnog broja životinja u istraživanju. Također, uravnoteženje uzgojnih uvjeta bi olakšalo procjene. Možemo zaključiti da za daljnje analize treba puno više podataka i mjerenja u svrhu dobivanja značajne aditivne genetske vrijednosti.

Istarska ovca je pasmina sa dobrom morfologijom vimena, koju je potrebno očuvati u budućim selekcijama. U daljnim analizama potrebno je povećati količinu podataka i dalje razmotriti genetske parametre za svojstva oblika vimena. Dobiveni genetski parametri pokazuju da bi visina cisterne ispod sisnog kanalića bila logičnija za selekciju od kuta koji sisa zatvara s okomicom vimena, zbog visokog heritabiliteta.

## 10. Literatura

- 1) Barillet F. (2007). Genetic improvement for dairy production in sheep and goats. *Small Ruminant Research* 70, 60-75. [online] <<http://www.sciencedirect.com/science/article/pii/S0921448807000090>> Pristupljeno 20. travnja 2017.
- 2) Bergonier D., de Cremoux R., Rupp R., Lagriffoul G. and Berthelot X. (2003). Mastitis of dairy small ruminants. *Vet Res* 34, 689-716.
- 3) Bruckmaier R. M. and Blum J. W. (1998). Oxytocin release and milk removal in ruminants. *J Dairy Sci* 81, 939-949.
- 4) Bruckmaier R. M., Paul G., Mayer H., Schams D. (1997). Machine milking of Ostfriesian and Lacaune dairy sheep: udder anatomy, milk ejection and milking characteristics, *J Dairy Res* 64, 163-172.
- 5) Caja G., Such X., Rovai M. (2000). Udder morphology and machine milking ability in dairy sheep. *Proceedings of the 6th Great Lakes Dairy Sheep Symposium*, Guelph, Canada. pp. 17.-40.
- 6) Cohen R. A. (2006). Introducing the GLMSELECT PROCEDURE for Model Selection. *Proceedings of the Thirty-First Annual SAS Users Group International Conference*
- 7) De La Fuente L. F, Fernández G., San Primitivo F. (1996). A linear evaluation system for udder traits of dairy ewes. *Livest Prod Sci* 45, 171–178.
- 8) Džidić A. 2013. Laktacija i strojna mužnja. Hrvatska mlijeckarska udruga, Zagreb, Hrvatska.
- 9) Džidić A., Kapš M., Bruckmaier R. M. (2004). Machine milking of Istrian dairy Crossbreed ewes: udder morphology and milking characteristics. *Small Rum Res* 55: 183-189.
- 10) Džidić A., Šalamon D., Kaić A., Salajpal K., Kapš M. (2009). Relationship between udder and milking traits during lactation in Istrian dairy crossbreed ewes. *Ital J Anim Sci* 8: 154-156.
- 11) Falconer D. S. and Mackay T. F. (1996). *Introduction to Quantitative Genetics*. Fourth edition. Addison Wesley Longman, Harlow, Essex, UK.
- 12) Fernandez G., Baro J. A., De La Fuente L. F. and San Primitivo F. (1997). Genetic parameters for linear udder traits of dairy ewes. *J Dairy Sci* 80, 601–605.
- 13) Fischer T. M., Van der Werf J. H. J, Banks R. G., Ball A. J. (2004). Description of lamb growth using random regression on field data. *Livest. Prod. Sci.* 89, 175–185.



- 14) Gelasakis A. I., Arsenos G., Valergakis G. E., Oikonomou G., Kiossis E. and Fthenakis G.C. (2012). Study of factors affecting udder traits and assessment of their interrelationships with milking efficiency in Chios breed ewes. *Small Ruminant Res* 103, 232–239.
- 15) Henderson C. (1975). Best linear unbiased estimation and prediction under a selection model. *Biometrics*. 31(2), 423-447.
- 16) Istarska ovca – Agroklub [online] <<https://www.agroklub.com/baza-stocarstva/ovcarstvo/istarska-ovca-40/>> Pristupljeno 21. ožujka 2017.
- 17) Kapš M., Čurik I., Baban M. (2010). Modeling variance structure of body shape traits of Lipizzan horses. *Journal of animal science* 88, 9: 286-2882.
- 18) Labuissière J. (1988). Review of physiological and anatomical factors influencing the milking ability of ewes and the organisation of milking. *Livest Prod Sci* 18(3-4), 253-274.
- 19) Legarra A., Ugarte E. (2005). Genetic parameters of udder traits, somatic cell score, and milk yield in Latxa sheep. *J Dairy Sci* 88, 2238–2245.
- 20) Marie-Etancelin C., Astruc J., Porte D., Larroque H., Robert-Granié C. (2005). Multiple-trait genetic parameters and genetic evaluation of udder-type traits in Lacaune dairy ewes. *Livest Prod Sci*, 97, 211 – 218.
- 21) Marie-Etancelin C., Rupp R., Casu S., Carta A. and Barillet F. (2001). New objectives of selection related to udder health, morphology and milkability in dairy sheep. In: *Book of abstracts of the 52nd Annual Meeting of the European Association for Animal Production*
- 22) Marnet P. G. and McCusick B. C. (2001). Regulation of milk ejection and milkability in small ruminants. *Livest Prod Sci* 70, 125-133.
- 23) Meyer K. (1989). Estimation of genetic parameters. *Evolution an animal breeding*, pp. 161-167, Oxford University Press.
- 24) Mioč B., Prpić I., Barač Z., Vnučec I. (2012). *Istarska ovca hrvatska izvorna pasmina*. Zagreb, Hrvatski savez uzgajivača ovaca i koza. Zagreb, Hrvatska.
- 25) Mrode R. A. (2005). *Linear Models for the Prediction of Animal Breeding Values*, 2th Edition. CABI Publishing.
- 26) Prpić Z., Pavić V., Mioč B., Vnučec I., Sušić V. (2008). Morfološke odlike vimena istarskih ovaca. *Stočarstvo* 62, 11-18.

- 27) SAS Institute Inc. 2011. SAS® 9.3 System Options: Reference, Second Edition. Cary, NC:SAS Institute Inc., USA.
- 28) Šalamon D. (2013). Oblik vimena, muznost i genetička raznolikost istarske ovce. Doktorska disertacija. Zagreb: Agronomski fakultet.
- 29) Šalamon D., Džidić A. (2014). Preferences of Istrian sheep udder shape type on farms that apply machine milking. *Acta agraria Kaposvariensis*. 18 Supplement 1, 166-172.
- 30) Wilson A. J., Reale, D., Clements, M. N., Morrissey, M. M., Postma, E., Walling, C. A., Kruuk, L. E. B., Nussey, D. H. (2010). An ecologist's guide to the animal model. *Journal of Animal Ecology*. 79, 13-26.

## Životopis

Petra Furdić rođena je 23.02.1993. godine u Zagrebu. Pohađala je O.Š. Sesvete te potom upisala III. gimnaziju u Zagrebu. Maturirala je 2011. godine i nakon završene srednje škole upisala je Agronomski fakultet sveučilišta u Zagrebu, smjer Animalne znanosti. Pri završenom preddiplomskom studiju na Agronomskom fakultetu, dobila je titulu *univ. bacc. ing. agr.* Potom upisuje diplomski studij na Agronomskom fakultetu u Zagrebu, smjer Genetika i oplemenjivanje životinja. Tijekom studija stječe iskustvo rada u laboratoriju. Stručnu praksu odradila je na Veterinarskom institutu u Zagrebu. Kompetentna je sa svim Microsoft Office programima. Za vrijeme studija radi kao edukator u Zoološkom vrtu grada Zagreba, sudjeluje u vođenju obrazovnih programa, na edukativnim događanjima i provođenju monitoringa životinja. Također radi u suvenirnici Zoološkog vrta. Izvrsno se služi engleskim jezikom u čitanju, pisanju i govoru. U slobodno vrijeme pjeva u zboru Concordia discors Filozofskog fakulteta i član je speleološkog društva u Speleološkom klubu Samobor.